

인공신경망을 이용한 지반의 액상화 가능성 판별

The Analysis of Liquefaction Evaluation in Ground Using Artificial Neural Network

이 송*¹ Lee, Song
박 형 규*² Park, Hyung-Kyu

Abstract

Artificial neural networks are efficient computing techniques that are widely used to solve complex problems in many fields. In this paper a liquefaction potential was estimated by using a back propagation neural network model applied to cyclic triaxial test data, soil parameters and site investigation data. Training and testing of the network were based on a database of 43 cyclic triaxial test data from 00 sites. The neural networks are trained by modifying the weights of the neurons in response to the errors between the actual output values and the target output value. Training was done iteratively until the average sum squared errors over all the training patterns were minimized. This generally occurred after about 15,000 cycles of training. The accuracy from 72% to 98% was shown for the model equipped with two hidden layers and ten input variables. Important effective input variables have been identified as the NOC, D_{10} and $(N_1)_{60}$. The study showed that the neural network model predicted a CSR(Cyclic shear stress Ratio) of silty-sand reasonably well. Analyzed results indicate that the neural-network model is more reliable than simplified method using N value of SPT.

요 지

인공신경망은 복잡한 상호관계를 가지는 문제의 해결을 위한 효과적인 컴퓨터 테크닉으로써 많은 분야에 활발히 활용되고 있다. 본 논문에서는 지반의 액상화 가능성을 판별하기 위하여 인공신경망 이론을 사용하였으며, 이를 위하여 반복삼축압축시험 결과와 토성자료, 지반조사자료 등을 학습인자로 사용하였다. 학습과 검증에 서해안지역의 43개의 반복삼축압축시험 데이터가 사용되었다. 여기서 인공신경망의 학습은 예측된 CSR과 실측한 CSR 사이의 오차가 적어지도록 신경망의 가중치를 수정하는 것으로 이루어진다. 전체 신경망에 대한 평균제곱의 오차가 허용치 이내로 감소할 때까지 학습은 반복되어 진행되며 일반적으로 15,000 이상의 학습이 요구되는 것으로 나타났다. 다양한 노드수를 가지는 신경망에 대한 학습을 수행한 결과, 1번째 은닉층의 수가 20개이고 2번째 은닉층의 수가 10개인 신경망이 72~98%에 해당되는 정밀도를 가지고 해당 전단변형률과 반복횟수에서의 CSR값을 예측할 수 있었다. 여기서 NOC(Number of Cycle)와 D_{10} , $(N_1)_{60}$ 등의 입력변수가 지반의 액상화 거동에 주요한 영향인자로 나타났다. 연구결과 인공신경망을 이용한 지반의 액상화 거동의 예측이 비교적 정확하게 산정됨을 알 수 있었으며, CSR과 $(N_1)_{60}$, NOC와의 관계가 기존의 연구 결과에 부합하여 나타남을 알 수 있었다.

Keywords : Artificial neural network, Back-propagation, CSR, Liquefaction potential

*1 정회원, 서울시립대학교 도시과학대학 토목공학과 교수 (Member, Prof., The Univ. of Seoul, Dept. of Civil Engrg., scugeo@sidae.uos.ac.kr)

*2 정회원, 서울시립대학교 도시과학대학 토목공학과 박사과정 (Member, Ph. D. Candidate, The Univ. of Seoul, Dept. of Civil Engrg.)

1. 서론

최근 국내에서는 좁은 국토의 효율적 활용 방안으로 공항, 공업단지 등을 연약지반이나 매립지반에 건설하고 있다. 그러나 이러한 지반에 지진이 발생할 경우 지반의 액상화로 인하여 상부 구조물에 상당한 피해를 야기시킬 수 있어 국내에서도 중요 구조물에 대한 액상화 대책을 위하여 내진 설계를 실시하고 있다. 이와 같은 내진설계를 위해 우선 액상화 가능성 유무를 입도분포와 N값 등을 이용하여 간이 예측을 수행하고, 예측결과 위험 가능성이 존재하는 지역에 대하여 실제와 유사한 가상의 지진력을 작용시킨 후 지반 특성을 파악하여 지진에 대한 위험도를 감소시키는 대책이 강구되는 것이 일반적이다. 그러나 간이 예측에 의한 액상화 가능성이 실제 상세 예측한 값과 다소 차이가 발생하는 실정이며, 보다 정확한 액상화 예측을 위하여 상세 예측을 수행하나 많은 시간과 비용이 소요되고 있다. 따라서 본 연구에서는 상세 예측을 통하여 산정된 지반의 전단강도응력비와 액상화에 영향을 미치는 주요인자들을 이용한 인공신경망의 학습을 수행하여 각 인자간의 상호관계를 파악한 후에 실제 지반의 액상화 가능성을 파악하였고, 상세 예측 정도의 정밀도를 가진 간이 예측이 가능하며, 보다 신속하고 정확한 액상화 가능성을 판별할 수 있으리라 판단된다.

2. 연구 동향

지반공학분야에서의 신경망은 1980년대 후반에서부터 활발한 연구가 진행되었다. Ellis(1992)가 인공신경망을 이용하여 모래의 공학적인 거동을 예측하였고, Anthony(1994)는 일본과 미국의 지진기록을 이용하여 신경망을 학습시키고 학습에 사용하지 않은 자료를 가지고 액상화 가능성을 평가한 결과 기존의 경험적인 방법에 비해 상당히 높은 정밀도를 가지고 예측 가능하다는 것을 보여주었고, 또한 액상화 가능성에 영향을 주는 주요인자를 파악할 수 있었다. 그리고 Anthony(1995)는 CPT field Data를 이용한 액상화 가능성을 평가하였고, 콘의 선단저항각과 반복 응력비 간의 관계 그리고 액상화 가능성간의 관계를 파악하였다.

3. 액상화 평가방법

액상화 평가방법은 지반의 액상화 저항강도와 지진으로 인한 지반 내에 작용하는 반복전단응력을 비교함으로써 이루어진다. 지반의 액상화 예측을 위한 평가방법에는 주로 지반의 표준관입시험에 의한 N값, 흙의 입도, 유효상재압 및 지표면 최대가속도 등과 액상화 거동과의 관계를 이용하는 간이 예측방법과 지진응답해석 및 실내 액상화 시험을 하여 이들로부터 구한 외력과 강도를 비교함으로써 액상화 발생가능성을 판별하는 상세 예측방법으로 크게 나누어 생각할 수 있다.

3.1 간이 액상화 평가방법

본 논문에서 사용된 간이 액상화 평가방법은 Seed와 Idriss(1983)에 의한 액상화 예측법으로써 지반의 N값, 유효상재압 및 지진규모 M을 이용하여 지반의 액상화 저항강도를 산정할 수 있다. 이를 위해 먼저 식 (1)의 유효상재압(σ_v , ton/m²)에 의한 N값 보정을 한다.

$$(N_1)_{60} = C_N \cdot N \quad (1)$$

$$C_N = 0.77 \log\left(\frac{20}{\sigma_v}\right) \quad (2)$$

그림 1은 Seed(1984) 등이 세립분 함량에 따른 $(N_1)_{60}$ 과 CSR과의 관계를 나타낸 것으로 위에서 구한 보정된 N값을 사용하여 CSR을 산정한다. 여기서 τ_{av} 는 허용전단응력이다.

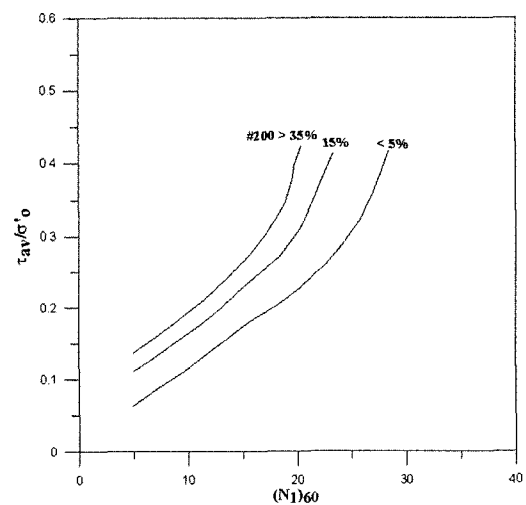


그림 1. M=7.5에서 실트질 모래에 대한 CSR과 $(N_1)_{60}$ 과의 관계 (Seed and Idriss, 1983)

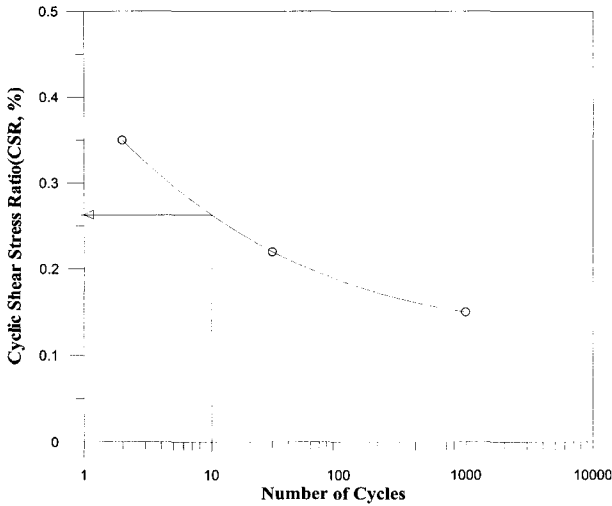


그림 2. 반복삼축시험에서 N=10회일 때 반복전단응력비

3.2 상세 액상화 평가방법

본 논문에서 사용된 상세 액상화 평가방법은 반복삼축압축시험을 이용한 방법으로 동일한 유효구속압으로 압밀시킨 후 축차응력을 변화시켜가면서 파괴가 발생하는 반복횟수와 CSR과의 관계로부터 액상화저항강도비를 산정한다. 즉, 그림 2와 같이 파괴에 이르게되는 반복재하횟수인 NOC값과 CSR과의 플롯에서 NOC가 10에 해당되는 상태에서의 CSR 값을 지반의 액상화 저항 강도비라 한다.

4. 인공신경망의 설계 및 적용

4.1 인공신경망의 설계

디지털 컴퓨터는 프로그램에 의해 순차적으로 업무를 수행할 뿐 인간과 같이 판단하며 인식할 수 있는 능력이 없기 때문에 인간 두뇌의 신경망 조직과 판단 과정을 모델링하여 프로그래밍 하는 것을 뉴로컴퓨터 또는 인공신경망이라 한다. 이러한 구조를 가진 신경망은 입력 데이터를 통하여 학습되어지는 특성을 가지며 프로그램 되지 않는다. 즉, 전통적인 방식의 컴퓨터와 같이 미리 정해진 순서에 따라 수행되는 프로그램이 아닌 입력값과 출력값이 주어지면 원하는 결과를 낼 수 있도록 학습하는 것이다. Eberhart(1990) 등은 신경망 이론에 역전파 이론을 적용할 때 그림 3과 같은 순서를 거쳐야 한다고 제안하였다.

다수의 데이터와 학습은 비선형 함수에 대한 정확한 이해를 가능하게 되므로 우선 다양한 조건을 가진 충분한 많은 데이터를 수집하여야 한다. 또한, 학습 후 수렴 정도

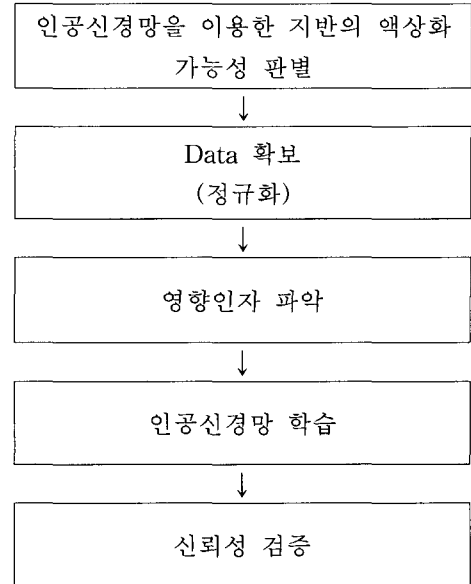


그림 3. 신경망 프로그래밍 흐름도

를 높이기 위해서는 인공신경망에 학습을 시키기 전에 데이터를 0~1사이의 값으로 정규화 하여야 한다. 본 논문에 사용된 정규화 방법은 Master(1993)의 방법을 따르기로 한다. 그러나 주요인자가 아닌 인자들을 이용한 학습은 오히려 정확도의 감소는 물론 수렴 여부도 불확실하게 되므로 입력 인자와 출력 인자간의 상관관계를 파악하여 최소한의 주요 영향인자를 파악하는 것이 중요하다.

인공신경망의 학습은 은닉층의 수와 은닉 층에서의 Node의 수를 변화시켜가며 오차 제곱의 합이 최소가 되는 신경망을 최적의 신경망으로 규정하여 학습을 수행하였다. 또한, 학습이 종료된 후에 학습에 사용되지 않은 데이터를 가지고 신경망의 신뢰성을 검증하여야 하며, 이때 검증에 사용되는 데이터의 정규화 된 입력 변수 값은 0~1 사이의 값을 가져야 한다. 만약 이 범위에 포함되지 않는다면 학습에 의한 Mapping된 범위를 벗어나게 됨으로써 신뢰성 검증에 합당한 결과를 산출하지 못하게 되는 우를 범하게 된다.

4.2 인공신경망의 적용 및 검증

본 인공신경망의 학습에 이용된 시험데이터는 총 43개로 이중에서 33개를 학습자료로 이용하였으며, 10개를 검증자료로 이용하였다. 시험데이터의 토질정수는 표 1과 같다.

반복삼축압축시험의 CSR를 예측하기 위하여 9개의 학습인자를 가지고 학습시킨 결과 첫 번째 은닉층과 두 번째 은닉층의 노드수가 각각 20, 10개 그리고 학습률

표 1. 학습에 이용된 시험데이터의 토질정수

토질정수	용어 정리	범 위
ϵ_r (%)	전단변형률	2%, 5%, 10%
$(N_1)_{60}$	에너지보정(60%) N	4.4 ~ 25
σ'_o (kg/cm ²)	유효응력	0.59 ~ 2.65
σ_o (kg/cm ²)	전응력	0.87 ~ 4.75
#200(%)	#200 통과량	33 ~ 72
D ₁₀ (mm)	유효입경	0.003 ~ 0.033
D ₃₀ (mm)	30% 통과시 입경	0.030 ~ 0.070
D ₆₀ (mm)	60% 통과시 입경	0.068 ~ 0.110

0.1, 모멘텀 상수가 0.1인 상태에서 학습오차가 가장 작게 나타났다. 그림 4와 같이 15,000번의 학습이 수행된 후의 학습오차가 5×10^{-5} 정도의 정밀도가 나와 충분한 정밀도를 가지고 학습이 수행됨이 나타났다. 또한 CSR에 영향을 미치는 인자에 대하여 상대적인 중요도를 파악한 결과 그림 5에서 보듯이 NOC와 D₁₀, (N₁)₆₀의 순서로 크게

영향을 미치는 것으로 나타났다. 여기서 상대적 중요도 판정은 Garson(1991)이 제안한 방법을 사용하도록 한다.

5. 신경망 결과 고찰

우선 설계한 인공신경망의 학습결과의 적용성의 타진과 CSR에 영향을 미치는 주요인자와의 상호관계를 알아보기 위하여 그림 6과 그림 7을 도시하여 보았다. 이에 임의의 조건에서의 파괴에 이르는 NOC에서의 CSR을 도시해본 결과 그림 6과 같이 NOC에 따라 CSR 값이 감소하며 임의의 CSR값에 수렴함을 알 수 있었다. 그림 7은 세립분 함량이 40.5%인 시료에 대하여 (N₁)₆₀과 CSR과의 관계를 도시하였다. 그 결과 Seed와 Idriss의 액상화 간이 평가방법에서 사용되는 그림 1의 경향

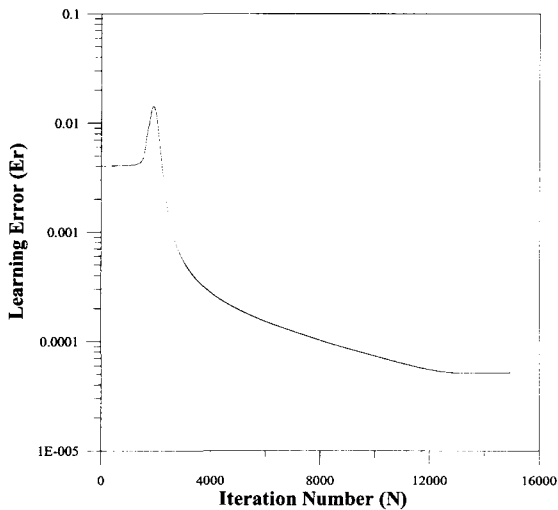


그림 4. 학습횟수에 따른 Er

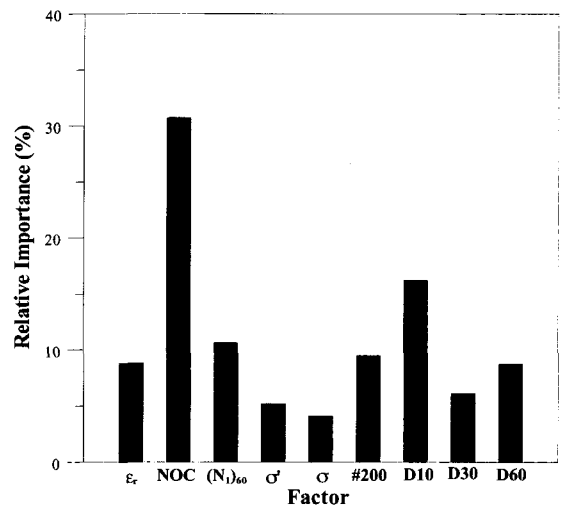


그림 5. 영향인자에 따른 상대적 중요도

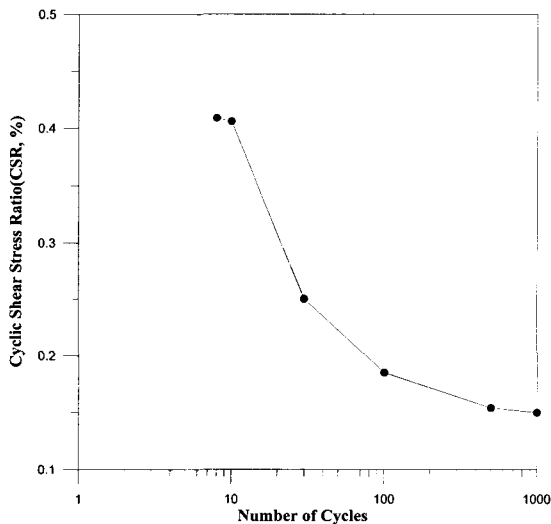


그림 6. NOC에 따른 전단응력비

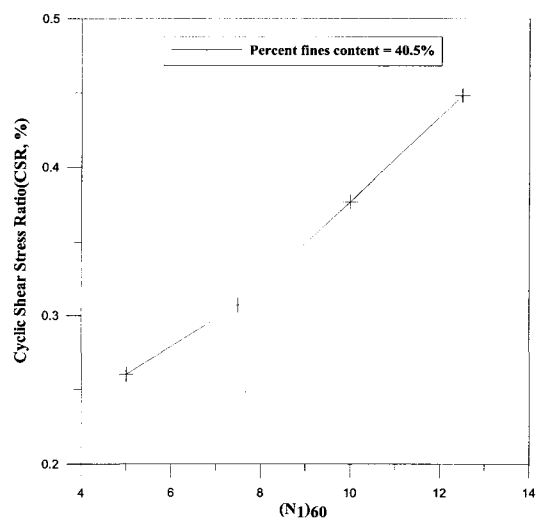


그림 7. (N₁)₆₀과 전단응력비와의 관계

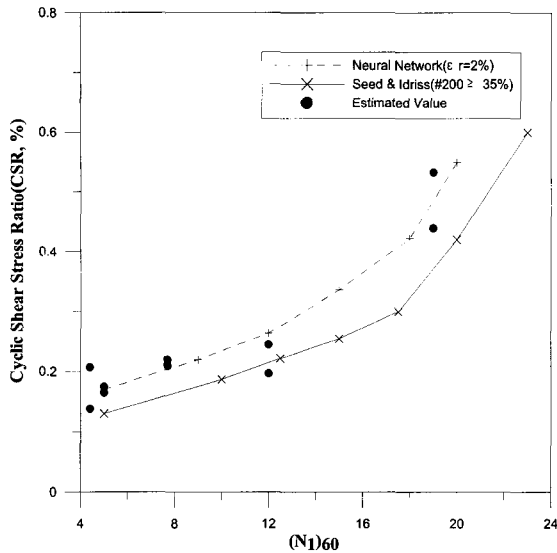


그림 8. $(N_1)_{60}$ 에 따른 CSR의 예측값과 실측값

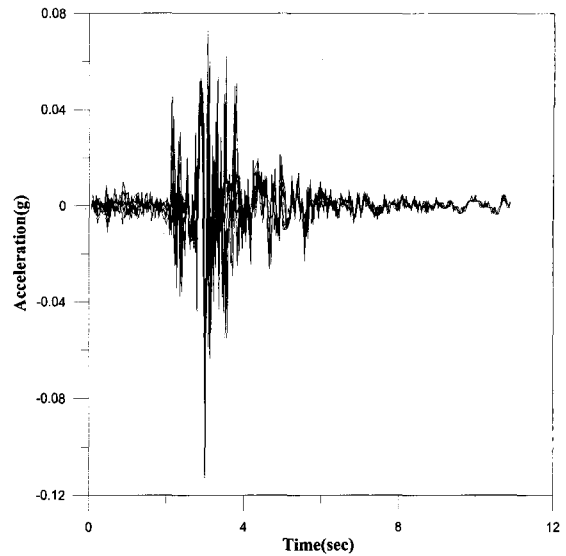


그림 9. 지반가속도의 시간이력

과 같이 $(N_1)_{60}$ 의 증가에 따라 CSR값이 증가함을 알 수 있었다. 여기서 그림 6, 7은 다른 영향인자를 고정시키고 주요인자인 NOC와 $(N_1)_{60}$ 을 변화시켜 CSR을 도사하였다.

아래 그림 8은 $(N_1)_{60}$ 에 따른 CSR값의 실측값과 예측값을 도사한 그림이다. 그 결과 인공신경망에 의한 CSR 산정시 약 72~98%에 해당하는 정밀도를 가짐을 알 수 있었다. 이에 비해 Seed와 Idriss의 간이 액상화 산정법에 의하여 산정된 CSR은 참값에 비하여 비교적 과소평가함을 알 수 있었다.

6. 지진응답분석 결과

지진응답분석을 위하여 SHAKE91에 사용한 입력자료로 그림 9와 같은 지반가속도의 시간이력, 지반의 동적 특성치와 지반의 Profile을 입력하였다. 여기서, Peak Acceleration(g)=0.11289, 지속시간(sec)=10.92으로, 20m 지반 Profile은 16층으로 구분하여 각각에 대해 입력 해석하였다. 그 결과 그림 10과 같이 지표 부분에 대한 액상화 가능성이 존재한 것으로 나타났으나, 하부로 갈수록 액상화에 대한 안정성이 높아지는 것으로 나타났다.

7. 결론

본 연구에서는 기존의 반복삼축압축시험 결과값과 지반조사 자료를 이용하여 인공신경망의 학습을 수행하여 실트질 점토에서의 CSR을 산정한 결과 다음과 같

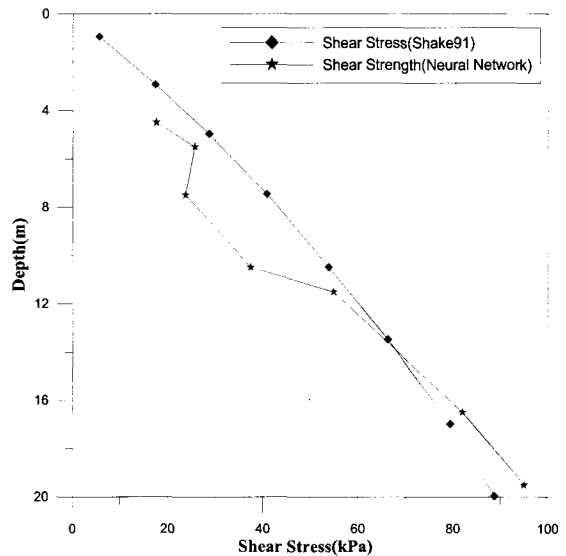


그림 10. 지반응답 해석결과

은 결과를 얻을 수 있었다.

- (1) 인공신경망 학습결과 CSR에 영향을 미치는 주요인자는 NOC와 D_{10} , $(N_1)_{60}$ 등으로 나타났다.
- (2) 인공신경망에 의하여 CSR값을 산정한 결과 약 72~98%에 해당하는 정밀도를 가짐을 알 수 있었다. 또한 Seed와 Idriss에 의하여 산정된 CSR값은 비교적 실측값에 비해 과소평가함을 알 수 있었다.
- (3) 인공신경망에 의하여 상세 예측에 비해 신속하고 간이 예측보다 정확한 지반의 액상화 가능성 판별이 가능하였다.
- (4) 보다 높은 정밀도를 가지는 신경망 모델의 설계를

위하여 보다 많고 다양한 학습자료가 필요하며 본 신경망의 설계과정에서 고려되지 못한 영향인자의 학습이 필요한 것으로 사료된다.

감사의 글

이 논문은 2001년도 서울시립대학교 학술연구조성비에 의하여 연구되었으며 이에 감사드립니다.

참 고 문 헌

1. Anthony T.C. Goh., 1994, "Seismic Liquefaction Potential Assessed by Neural Network", *J. Geotech. Engng. ASCE*, Vol.120, No.9, pp.1467-1480.
2. Anthony T.C. Goh., 1996, "Neural-Network Modeling of CPT Seismic Liquefaction Data", *J. Geotech. Engng. ASCE*, Vol.122, No.1, pp.70-73.
3. Eberhart, R. C., and Dobbins, R. W., 1990, "Neural network PC tools: A practical guide.", Academic Press, San Diego, Calif.
4. Ellis, G. W(1992), "Neural network modeling of the mechanical behavior of sand." *Proc., 9th Conf. ASCE Engrg. Mech., ASCE*, New York, N. Y., pp.421-424.
5. Garson, G. D., 1991, "Interpreting neural-network connection weights." *AI Expert*, 6(7), pp.47-51.
6. Master, T., 1993, "Practical neural network recipes in C++", Academic Press, San Diego, Calif.
7. Seed, H.B. and Idriss I.M., Ignacio Arango., "Evaluation of Liquefaction Potential using Field Performance Data", 1983, *J. GED, ASCE*, Vol.109, No.3, pp.458-483.

(접수일자 2002. 2. 20, 심사완료일 2002. 10. 10)